


Detekcja i śledzenie ruchomych obiektów w obrazie

Piotr Dalka

Plan prezentacji

- 
- Wprowadzenie
 - Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
 - Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Wprowadzenie

- Usuwanie (odejmowanie) tła i śledzenie obiektów są pierwszymi etapami w większości aplikacji z dziedziny przetwarzania obrazów dotyczących np. nadzoru i monitoringu lub indeksowania danych multimedialnych
- Celem usuwania tła jest wykrycie ruchomych obiektów pierwszoplanowych w analizowanych scenach
- Celem śledzenia obiektów jest zachowanie ciągłości analizy ich ruchu w czasie ich obecności w polu widzenia kamery

Plan prezentacji

- **Wprowadzenie**
- Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
- Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Wykrywanie obiektów ruchomych

- Dwie główne grupy metod detekcji obiektów ruchomych (usuwania tła):
 - Przepływ optyczny (ang. optical flow)
 - Odejmowanie tła (ang. background subtraction)

Przepływ optyczny


- Zbiór translacji (w postaci pola wektorowego), które przekształcają dany obraz w sekwencji w następny obraz w sekwencji

$$I_t(x, y) = I_{t-1}[x + O(x, y, 0), \quad y + O(x, y, 1)]$$

Przepływ optyczny

- Wyróżnia się:
 - metody gradientowe – bazują na analizie pochodnych (przestrzennych i czasowych) intensywności obrazu
 - metody w dziedzinie częstotliwości – oparte na filtrowaniu informacji obrazowej w dziedzinie częstotliwości
 - metody korelacyjne – bazujące na odpowiedniości obszarów obrazów
- Metody bardzo złożone obliczeniowo

Przepływ optyczny - przykład



Odejmovanie tła

- W ogólności polega na:
 - Wyznaczeniu obrazu referencyjnego
 - Obliczeniu różnicy między bieżącą ramką sygnału, a obrazem referencyjnym
 - Wyznaczeniu maski binarnej oznaczającej, które piksele obrazu należą do ruchomych obiektów



Odejmovanie tła

- Najprostsza metoda wyznaczenia obrazu referencyjnego – pojedyncza ramka obrazu bez ruchomych obiektów
 - trudna do uzyskania w praktyce
 - brak adaptacji
- Najprostsza metoda dająca się zastosować praktycznie: uśrednianie wykładnicze

$$M_t(x, y) = (1 - \alpha) \cdot M_{t-1}(x, y) + \alpha \cdot I(x, y)$$

- Algorytm odejmowania tła musi być adaptacyjny i nieustannie uaktualniać model tła

Plan prezentacji

- Wprowadzenie
- Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
 - Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Modelowanie tła

- Każdy piksel obrazu jest modelowany jako suma ważonych funkcji Gaussowskich (ang. Gaussian mixture)
- Gęstość prawdopodobieństwa rozkładu normalnego:

$$\eta(\mathbf{x}_t, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{0.5 \cdot D} \sqrt{|\boldsymbol{\Sigma}|}} e^{-0.5 \cdot (\mathbf{x}_t - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x}_t - \boldsymbol{\mu})}$$

- \mathbf{x}_t – wartość (RGB) piksela w czasie t
- $D = 3$ – ilość elementów opisujących kolor piksela
- $\boldsymbol{\mu}$ i $\boldsymbol{\Sigma}$ – wektor wartości średnich i macierz kowariancji rozkładu

Modelowanie tła

- Każdy piksel obrazu jest modelowany jako suma ważonych funkcji Gaussowskich (ang. Gaussian mixture)
- Prawdopodobieństwo, że w czasie t piksel przyjmie wartość x_t jest dane wzorem:

$$p(\mathbf{x}_t) = \sum_{i=1}^K w_t^i \eta(\mathbf{x}_t, \boldsymbol{\mu}_t^i, \boldsymbol{\Sigma}_t^i)$$

- η – gęstość prawdopodobieństwa rozkładu normalnego
- w_t^i – waga rozkładu (ich suma = 1)
- $\boldsymbol{\mu}_t^i$ i $\boldsymbol{\Sigma}_t^i$ – wektor wartości średnich i macierz kowariancji
- K – ilość rozkładów opisujących piksel (zwykle 3 – 5)

Modelowanie tła

- W celu zmniejszenia złożoności obliczeniowej założono niezależność statystyczną wartości poszczególnych składowych koloru:

$$\boldsymbol{\Sigma}_i = \begin{bmatrix} \sigma_{Ri}^2 & 0 & 0 \\ 0 & \sigma_{Gi}^2 & 0 \\ 0 & 0 & \sigma_{Bi}^2 \end{bmatrix}$$

Modelowanie tła

- Każdy piksel obrazu opisany jest za pomocą $K \cdot 7$ parametrów (waga w , wartości średnie μ składowych koloru RGB oraz ich wariancje σ^2)
- Wielkość modelu tła ($K = 5$, float = 32 bit):
 - dla PAL (704x576): 54 MB
 - dla Full HD (1920x1080): 277 MB
- Wymagana przepustowość pamięci (fps=15) co najmniej:
 - dla PAL (704x576): 810 MB/s
 - dla Full HD (1920x1080): 4155 MB/s

Modelowanie tła

- Im częściej dany piksel przyjmuje określony kolor, tym większa szansa, że kolor ten odpowiada kolorowi tła
- Rozkład najlepiej opisujący kolor tła charakteryzuje się dużą wagą i małymi wariancjami, a wartości średnie rozkładu dążą do rzeczywistego koloru tła

Modelowanie tła

- Parametry opisujące piksele są uaktualniane wraz z każdą nową ramką obrazu wejściowego
- Dla danego piksela sprawdzane jest, który rozkład pasuje do bieżącej wartości piksela
- Rozkłady są sprawdzane w kolejności malejącej wartości współczynnika

$$r = \frac{w}{\sqrt{|\Sigma|}}$$

aż do znalezienia pierwszego pasującego rozkładu

Modelowanie tła

- Bieżący kolor piksela pasuje do rozkładu, jeśli każda jego składowa RGB leży w granicach $\pm 2,5$ odchyłeń standardowych od wartości średniej
- W przypadku, gdy żaden rozkład nie pasuje do bieżącego koloru, rozkład o najmniejszej wartości współczynnika r jest zastępowany nowym o dużej wariancji, małej wadze i wartości średniej równej bieżącemu kolorowi

Modelowanie tła

- Wagi wszystkich rozkładów dla danego piksela są uaktualniane wg wzoru, a następnie normalizowane:

$$w_t = (1 - \alpha)w_{t-1} + \alpha M_t$$

$M_t = 1$ dla pasującego rozkładu, a 0 – dla pozostałych
 α – współczynnik szybkości adaptacji (od 0 do 1)

- Wartości średnie i wariancje pasującego rozkładu dla każdej składowej RGB uaktualniane są zgodnie z wyrażeniami:

$$\mu_t = (1 - \alpha)\mu_{t-1} + \alpha \cdot x_t$$

$$\sigma_t^2 = (1 - \alpha)\sigma_{t-1}^2 + \alpha(x_t - \mu_t)^2$$

Modelowanie tła


- Przyjmuje się, że model tła dla danego piksela jest tworzony przez pierwszych D rozkładów posortowanych wg malejącej wartości współczynnika r
- D jest wyznaczane wg wzoru:

$$D = \arg \min_d \left(\sum_{i=1}^d w_i^t > T \right)$$

- Próg T wyznacza, jaka część rozkładów modelujących kolor piksela zostanie uznana za bieżący model tła

Modelowanie tła

- Jeśli T jest małe, model tła jest zwykle jednomodowy
- Wielomodowy rozkład tła oznacza, że może zawierać on kilka różnych kolorów i w ten sposób prawidłowo reagować na cykliczne zmiany w tle
- Jeśli bieżący kolor piksela nie pasuje do żadnej z pierwszych D dystrybucji, to jest uznawany za obiekt ruchomy



Modelowanie tła

Bieżąca ramka



Model tła –
rozkład o
największej
wadze




Czas T

Czas $T + 13$ minut

Modelowanie tła - wydajność

- Komputer Intel Xeon W3530 @ 2,80GHz
- Obraz oryginalny i o zmniejszonej rozdzielczości



Plan prezentacji

- Wprowadzenie
- Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
- Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Detekcja cieni obiektów


- Cień obiektu jest obecny praktycznie zawsze i poruszając się razem z obiektem jest klasyfikowany jako część tego obiektu
- Wykrywanie cienia bazuje na dwóch faktach:
 - zacienione tło sceny posiada mniejszą jasność, ale praktycznie niezmienną barwę
 - tekstura zacienionego tła sceny pozostaje niezmienna



Detekcja cieni obiektów

- Różnica w jasności b pomiędzy bieżącym pikselem I a kolorem opisany rozkładem E wynosi:

$$b = \arg \min_{\alpha} (\mathbf{I} - \alpha \cdot \mathbf{E})^2$$




- Różnicę w kolorze c wyznacza się z zależności:

$$c = \|\mathbf{I} - b \cdot \mathbf{E}\|$$

- Ponieważ założono, że składowe koloru są niezależne, różnicę c wyznacza się oddzielnie dla każdej składowej RGB jako:

$$c_{RGB} = I_{RGB} - b \cdot E_{RGB}$$

Detekcja cieni obiektów



- Sprawdzaniu pod kątem występowania cienia podlegają tylko te piksele, które zostały zakwalifikowane jako należące do obiektów ruchomych
- Jeśli
 - różnica jasności $T_b < b < 1$, i
 - każda różnica w kolorze c_{RGB} leży w granicach $\pm 2,5$ odchyłeń standardowych przynajmniej jednego z D pierwszych rozkładów tworzących model tła,to dany piksel jest uznawany za cień i klasyfikowany jako należący do tła
- T_b ogranicza liczbę ciemnych pikseli błędnie klasyfikowanych jako cień

Detekcja cieni obiektów




- W dalszym etapie brane pod uwagę są tylko piksele zakwalifikowane jako cień na podstawie porównania barwy i jasności
- Założenie o stałości tekstury
- Jako miarę tekstury wykorzystano operator Sobela (gradient obrazu w kierunku poziomym i pionowym)
- Jeśli różnica pomiędzy gradientem obrazu w najbliższym otoczeniu wybranego punktu a gradientem bieżącego modelu tła w tym samym otoczeniu jest większa niż założony próg – nie mamy do czynienia z cieniem

Plan prezentacji

- Wprowadzenie
- Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
- Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Przetwarzanie masek binarnych

- W wyniku dotychczasowych operacji otrzymuje się maskę binarną zawierającą piksele należące do wykrytych obiektów ruchomych
- Celem przetwarzania morfologicznego i czasowego jest uzyskanie rozdzielonych, jednolitych obszarów oznaczających ruchome obiekty




Przetwarzanie masek binarnych

- Operacje morfologiczne:
 - Usuwanie obiektów (połączonych pikseli) mających mniej niż określoną liczbę pikseli
 - Jeśli piksel ma w swoim najbliższym sąsiedztwie (3x3) przynajmniej 5 pikseli o wartości 1, to przyjmuje wartość 1; w przeciwnym wypadku – 0





Przetwarzanie masek binarnych

- Operacje morfologiczne c.d.:
 - Zamykanie (dylatacja, a następnie erozja)
 - dylatacja – jeśli w najbliższym sąsiedztwie piksela jest choć jeden piksel o wartości 1, to piksel ten też przyjmuje wartość 1
 - erozja - jeśli w najbliższym sąsiedztwie piksela jest choć jeden piksel o wartości 0, to piksel ten też przyjmuje wartość 0




Przetwarzanie masek binarnych

- Operacje morfologiczne c.d.:
 - Wypełnianie dziur (obszarów o wartości 0, otoczonych „jedynkami”)



Detekcja ruchomych obiektów



Bieżąca ramka

Bezpośredni wynik
odejmowania tła


Po przetworzeniu
morfologicznym

Detekcja obiektów - przykłady



Detekcja obiektów - przykłady

- Nagłe zmiany oświetlenia



Detekcja obiektów - przykłady

- Trudne warunki atmosferyczne





Plan prezentacji

- Wprowadzenie
- Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
 - Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Śledzenie ruchomych obiektów

- Śledzenie obiektów (ang. object tracking) ma za zadanie zapewnienie ciągłości i jednoznaczności identyfikacji każdego ruchomego obiektu w obrazie na cały czas jego obecności w strumieniu wizyjnym
- Oczekiwany efekt działania algorytmu - ciągła trajektoria ruchu każdego obiektu pojawiającego się w scenie



Metody śledzenia obiektów

- Dwa rodzaje procesów składających się na śledzenie obiektów:
 - reprezentacja i lokalizacja obiektów (ang. Target Representation and Localization)
 - filtracja i asocjacja danych (ang. Filtering and Data Association)

Metody śledzenia obiektów

- Reprezentacja i lokalizacja obiektów:
 - stanowi podejście „od szczegółu do ogółu”
 - zajmuje się opisem cech obiektu i na tej podstawie lokalizowaniem obiektu w kolejnych ramkach
 - musi sobie radzić z możliwymi zmianami w wyglądzie obiektów

Metody śledzenia obiektów

- Reprezentacja i lokalizacja obiektów - przykładowe realizacje:
 - bazujące na gradiencie i wykorzystujące kryterium korelacji
 - stworzenie modelu obiektu wykorzystującego niezmiennie cechy struktury obrazu obiektu (np. kolor, geometria) i informacje o jego ruchu
 - użycie kaskady klasyfikatorów AdaBoost do śledzenia poszczególnych obiektów; każdemu wykrytemu obiektowi jest przypisywany jeden trenowany w czasie rzeczywistym klasyfikator, który znajduje lokalizację tego obiektu w kolejnych ramkach

Metody śledzenia obiektów

- Filtracja i asocjacja danych:
 - stanowi podejście „od ogółu do szczegółu”
 - zajmuje się dynamiką ruchu obiektów
 - można ją w najbardziej ogólny sposób zdefiniować wykorzystując podejście przestrzeni stanów w modelowaniu dynamicznych systemów dyskretno-czasowych

Metody śledzenia obiektów

- Filtracja i asocjacja danych:
 - obiekt modelowany jest za pomocą sekwencji stanów $\{x_k\}_{k=0,1,\dots}$ których zmiany w czasie są określone przez dynamiczne równanie $x_k = f_k(x_{k-1}, v_k)$
 - Zmierzone dane $\{z_k\}_{k=1,\dots}$ są powiązane z odpowiadającymi im stanami równaniem pomiaru $z_k = h_k(x_k, n_k)$
 - W ogólności, f_k i h_k są nieliniowymi, zmiennymi w czasie funkcjami odwzorowującymi rzeczywiste liczby na wektory
 - Zakłada się, że każda sekwencja szumu $\{v_k\}_{k=1,\dots}$ $\{n_k\}_{k=1,\dots}$ jest niezależna i cechuje się identycznym rozkładem

Metody śledzenia obiektów

- Filtracja i asocjacja danych:
 - celem śledzenia obiektów jest oszacowanie stanu x_k z wykorzystaniem wszystkich dotychczas zmierzonych wielkości $\{z_k\}_{k=1:k}$ lub (równoważnie) określenie funkcji gęstości prawdopodobieństwa $p(x_k | z_{1:k})$

Metody śledzenia obiektów

- Filtracja i asocjacja danych – przykładowe realizacje:
 - filtr Kalmana (ang. Kalman Filter) – gdy sekwencje szumowe mają rozkład normalny oraz funkcje f_k i h_k są liniowe
 - rozszerzony filtr Kalmana (ang. Extended Kalman Filter) – gdy funkcje f_k i h_k są nieliniowe
 - bezśladowy filtr Kalmana (ang. Unscented Kalman Filter) – może być stosowany do modeli nieliniowych i nie-Gausowskich

Metody śledzenia obiektów

- Filtracja i asocjacja danych – przykładowe realizacje:
 - Ukryte Modele Markowa (ang. Hidden Markov Models) – gdy wykorzystywana przestrzeń stanów jest dyskretna i składa się ze skończonej liczby stanów
 - filtry cząsteczkowe (ang. Particle Filters) – bazują na metodach całkowania Monte Carlo

Metody śledzenia obiektów

- Sposób i stopień, w jaki procesy reprezentacji i lokalizacji obiektów oraz filtracji i asocjacji danych są wykorzystywane w konkretnej aplikacji śledzenia obiektów zależą od przeznaczenia danej aplikacji oraz determinują skuteczność jej działania
- Wymaga się, aby proces śledzenia obiektów był jak najmniej złożony obliczeniowo, ponieważ w systemach działających w czasie rzeczywistym zdecydowana część mocy obliczeniowej jest przeznaczona na inne zadania, z reguły wysokopoziomowe, takie jak identyfikacja obiektów czy wykrywanie zdarzeń

Plan prezentacji

- Wprowadzenie
- Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
 - Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Filtr Kalmana

- Filtr Kalmana to algorytm rekurencyjnego wyznaczania minimalno-wariancyjnej estymaty wektora stanu modelu liniowego, dyskretnego układu dynamicznego na podstawie pomiarów wyjścia tego układu
- Przyjmuje się założenie, że zarówno pomiar, jak i proces przetwarzania wewnątrz układu jest obarczony błędem o rozkładzie gaussowskim
- Zalety: stosunkowo łatwa implementacja, niska złożoność obliczeniowa oraz dobra skuteczność działania

Filtr Kalmana

- Pozwala na estymowanie stanu $x \in R^n$ procesu dyskretno-czasowego, który może być opisany stochastycznym równaniem różnicowym:

$$x_k = Ax_{k-1} + Bu_{k-1} + w_{k-1}$$

- Wykorzystuje wektor pomiarowy $z \in R^m$:

$$z_k = Hx_k + v_{k-1}$$

- u_k – opcjonalne wejście kontrolne
- w_k, v_k – niezależne zmienne losowe reprezentujące odpowiednio szum przetwarzania i szum pomiarowy:

$$p(w) \sim N(0, Q) \quad p(v) \sim N(0, R)$$

Filtr Kalmana

$$x_k = Ax_{k-1} + Bu_{k-1} + w_{k-1}$$

$$z_k = Hx_k + v_{k-1}$$

- Macierz przejścia A o wymiarach $n \times n$ wiąże stan procesu x w kroku poprzednim ze stanem w kroku bieżącym
- Macierz wejściowa B o wymiarach $n \times 1$ wiąże opcjonalne wejście kontrolne ze stanem procesu x
- Macierz wyjściowa H o wymiarach $m \times n$ wiąże stan procesu z bieżącym wektorem pomiarowym z

Filtr Kalmana

- Filtr Kalmana estymuje proces w określonym momencie czasu z wykorzystaniem zwrotnej informacji o bieżącym (i zaszumionym) wyniku pomiaru
- Równania filtru Kalmana dzielą się na:
 - równania aktualizacji czasu
 - równania aktualizacji pomiarów

Filtr Kalmana

- Równania aktualizacji czasu:
 - dokonują predykcji stanu układu w przód w celu otrzymania estymaty *a priori* \hat{x}_k^- stanu układu w kolejnym kroku czasowym

$$\hat{x}_k^- = A\hat{x}_{k-1} + Bu_{k-1}$$

$$P_k^- = AP_{k-1}A^T + Q$$

- P_k^- – estymata *a priori* błędu kowariancji
- P_k – estymata *a posteriori* błędu kowariancji

Filtr Kalmana

- Równania aktualizacji pomiarów:
 - są odpowiedzialne za sprzężenie zwrotne, tj. za włączenie nowych wyników pomiarów do estymaty *a priori* stanu procesu w celu uzyskania estymaty *a posteriori* \hat{x}_k

$$K_k = P_k^- H^T (H P_k^- H^T + R)^{-1}$$

$$\hat{x}_k = \hat{x}_k^- + K_k (z_k - H \hat{x}_k^-)$$

$$P_k = (I - K_k H) P_k^-$$

- K_k – wzmacnienie filtru Kalmana (im większe tym większy wpływ wartości pomiarowych na estymatę stanu procesu)

Plan prezentacji

- Wprowadzenie
- Metody wykrywania obiektów ruchomych
 - Podstawowe metody
 - Modelowanie tła
 - Usuwanie cienia
 - Przetwarzanie morfologiczne
- Metody śledzenia ruchomych obiektów
 - Informacje ogólne
 - Filtry Kalmana
 - Zastosowanie filtrów Kalmana do śledzenia obiektów

Śledzenie obiektów za pomocą filtrów Kalmana

- Każdemu wykrytemu obiektowi przypisywany jest oddzielny filtr Kalmana, zwany trackerem
- Ruchomy obiekt reprezentowany jest przez prostokąt
- Dwa możliwe postacie wektora stanu filtru Kalmana:

- sześćcioelementowy

$$x^6 = [x \quad y \quad w \quad h \quad dx \quad dy]^T$$

- ośmioelementowy


$$x^8 = [x \quad y \quad w \quad h \quad dx \quad dy \quad dw \quad dh]^T$$

- Wektor pomiarowy ma postać

$$z = [x^b \quad y^b \quad w^b \quad h^b]^T$$

Śledzenie obiektów za pomocą filtrów Kalmana

- Zachowanie filtru Kalmana z wektorem stanu x^8 (górny rząd) i x^6 (dolny rząd)



Śledzenie obiektów za pomocą filtrów Kalmana

- Macierze przejścia A i H przedstawiają się następująco:

$$A^s = \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad A^e = \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad x_k \cong Ax_{k-1}$$

$$H^s = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix} \quad H^e = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} \quad z_k \cong Hx_k$$

- Nie ma potrzeby korzystania z wejść kontrolnych więc macierz B jest równa 0

Śledzenie obiektów za pomocą filtrów Kalmana

- Warunki początkowe:
 - nowemu obiektowi przypisywany tracker z wektorem stanu:

$$\hat{x}_{-1}^s = [x_{-1}^b \quad y_{-1}^b \quad w_{-1}^b \quad h_{-1}^b \quad 0 \quad 0 \quad 0 \quad 0]^T$$

$$\hat{x}_{-1}^e = [x_{-1}^b \quad y_{-1}^b \quad w_{-1}^b \quad h_{-1}^b \quad 0 \quad 0]^T$$

- w następnym kroku czasowym (ramce) uaktualniane:

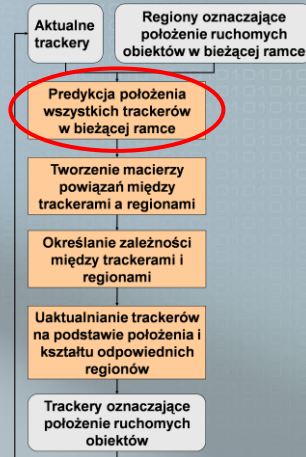
$$\hat{x}_0^s = [x_0^b \quad y_0^b \quad w_0^b \quad h_0^b \quad x_{-1}^b - x_0^b \quad y_{-1}^b - y_0^b \quad w_{-1}^b - w_0^b \quad h_{-1}^b - h_0^b]^T$$

$$\hat{x}_0^e = [x_0^b \quad y_0^b \quad w_0^b \quad h_0^b \quad x_{-1}^b - x_0^b \quad y_{-1}^b - y_0^b]^T$$

$$\hat{P}_0 = 1$$

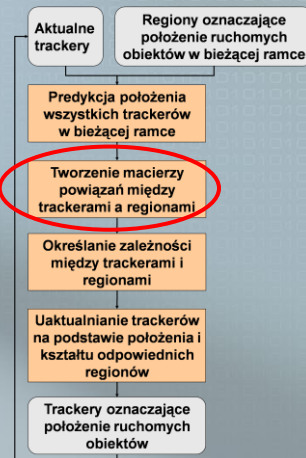
Algorytm śledzenia obiektów

- Dla każdej ramki obrazu dokonuje się:
 - predykcji w przód wektora stanu wszystkich filtrów Kalmana przypisanych do istniejących obiektów w celu otrzymania estymaty *a priori* położenia obiektów w bieżącej ramce obrazu



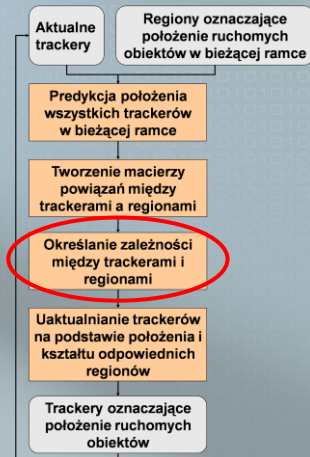
Algorytm śledzenia obiektów

- Dla każdej ramki obrazu dokonuje się:
 - tworzenie binarnej macierz powiązań – każdej parze tracker-region przypisana jest wartość 0 lub 1 w zależności od tego, czy prostokąty otaczające region oraz pozycję obiektu estymowaną przez tracker mają część wspólną



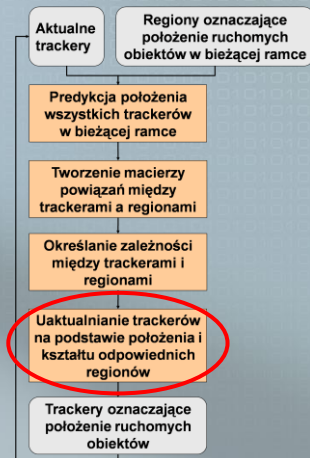
Algorytm śledzenia obiektów

- Dla każdej ramki obrazu dokonuje się:
 - ustalania poprawnych relacji pomiędzy wykrytymi obszarami należącymi do obiektów ruchomych w bieżącej ramce a rzeczywistymi, ruchomymi obiektami reprezentowanymi przez trackery









Algorytm śledzenia obiektów

- Dla każdej ramki obrazu dokonuje się:
 - korekcji wektorów stanu każdego obiektu w oparciu o parametry odpowiednich obszarów należących do wykrytych ruchomych obiektów





Relacje między regionami i trackerami

Typ relacji		Akcja
	Region bez żadnego trackera	Tworzony jest nowy tracker w oparciu o parametry regionu
	Tracker bez żadnego regionu	Przeprowadzana jest tylko predykcja stanu trackera; jeśli tracker nie zostanie powiązany z żadnym regionem przez pewien czas, jest usuwany
	Jeden tracker – jeden region	Tracker jest uaktualniany w oparciu o parametry regionu
	Jeden tracker – wiele regionów	Tracker jest uaktualniany w oparciu o parametry obszaru pokrywającego wszystkie regiony
	Wiele trackerów – jeden region	Każdy tracker jest uaktualniany w oparciu o parametry regionu
	Wiele trackerów – wiele regionów	Iteracyjna analiza grup region-tracker i uaktualnianie trackerów za pomocą najbardziej pasujących regionów, znajdujących na podstawie porównania ich wyglądu


Śledzenie obiektów - przykłady

■ Różne warunki oświetleniowe



Śledzenie obiektów - przykłady

- Rozwiązywanie konfliktów



Śledzenie obiektów - przykłady

- Rozwiązywanie konfliktów

